



استخدام الشبكات العصبية الاصطناعية للتنبؤ بأهم الخصائص الميكانيكية للبيتون المحلي تحت تأثير الضغط المحوري

بيلسان محمد¹، سليمان العامودي²، عبد الرحمن عيسى³*

¹ جامعة البعث، حمص، سوريا، Email: baylasan_m@hotmail.com

² أستاذ مساعد في قسم الهندسة الإنشائية جامعة البعث، حمص، سوريا، Email: dr.s.amoudi.1@gmail.com

³ أستاذ في قسم الهندسة الإنشائية جامعة البعث، حمص، سوريا.

* بيلسان محمد، Email: baylasan_m@hotmail.com

نشر في: 31 آذار 2020

الخلاصة – تعتمد خصائص البيتون بشكل كبير على المواد المحلية المستخدمة في تحضيره، وإن إجراء التجارب على البيتون الذي تقدمه معامل البيتون المجهول في المنطقة، يوضح السلوك الفعلي للبيتون المحضر من مواد محلية. في البرنامج التجريبي لهذا البحث تم صب ست أسطوانات قياسية (D=150 mm, H=300 mm) من معظم خلطات مجايل المنطقة الوسطى في سوريا (13 خلطة)؛ بحيث تغطي مجالاً عريضاً من المقاومة على الضغط (22 ← 46.5) MPa، تم إجراء الاختبارات باستخدام جهاز الكسر المخصص لهذا الغرض، والذي يعطي قيمة القوة المطبقة والانتقال المقابل بشكل متزامن حتى الانكسار. رسمت المنحنيات الوسطية الممثلة لعلاقة (الإجهاد- التشوه) للخلطات البيتونية المختبرة. ومنها تم إيجاد الخصائص الميكانيكية لكل خلطة متمثلة بمعامل المرونة E_c ، والإجهاد المحوري عند الذروة f'_c ، والتشوه المحوري الموافق ϵ_{co} . دُرِّبَت شبكات عصبية اصطناعية (باستخدام برنامج MATLAB) على نتائج الاختبارات التجريبية، وقد تبين استيعابها لقوانين سلوك البيتون بشكل جيد، وإمكانية استخدامها كطريقة بديلة عن النماذج الرياضية المتوفرة لعلاقة (إجهاد- تشوه) البيتون من خلال التنبؤ المباشر بالمنحني لمختلف الخلطات البيتونية التي تم تحضيرها من مواد محلية وبنسب خلط مختلفة، أو كطريقة مكملة لهذه النماذج من خلال اعتماد نموذج رياضي ملائم ومن ثم التنبؤ بأهم معاملاته (E_c ، f'_c ، ϵ_{co}). حيث أثبتت الشبكات العصبية الاصطناعية قدرتها على التنبؤ بالخصائص الميكانيكية للبيتون، وتوقعها على معادلات الانحدار الخطي بشكل كبير، مما يعد بتنبؤات أكثر دقة وشمولية.

الكلمات الرئيسية – إجهاد-تشوه، معامل مرونة، الشبكات العصبية الاصطناعية.

1. المقدمة

(إجهاد- تشوه) البيتون [4,5,6] يتحكم بخسن تمثيلها للمنحني تعويض القيم الفعلية لمعاملات النموذج المتمثلة في الغالب بمعامل المرونة E_c ، والإجهاد المحوري عند الذروة f'_c ، والتشوه المحوري الموافق ϵ_{co} . وبشكل عام بات سلوك البيتون حتى المقاومة القصوى معروفاً، إلا أن الجزء الهابط في المنحني وسلوك البيتون على اختلاف مقاوماته شكلوا مادة مهمة لدراسات وأبحاث متتالية. ومع انتشار الشبكات العصبية الاصطناعية قام بعض الباحثين [7] بدراسة إمكانية استخدامها للتنبؤ بمقاومة البيتون ومعامل مرونته حيث تم تغذية طبقة المدخلات بقيم تمثل كميات المواد المستخدمة لإنتاج متر مكعب واحد من البيتون، وصُمِّمَت فيه شبكتين (network1، network2) لا تختلفان عن بعضهما إلا بمستوى التسامح (tolerance) (0.01، 0.02) على التوالي. استطاعت الشبكة الأولى network1 الحصول على نتائج مرضية بالنسبة لمعامل المرونة، بينما لم تكن العملية متقاربة خلال خطوة التدريب بسبب مستوى التسامح (tolerance) المستخدم في الشبكة الثانية network2، وتبين أن دقة الإجابات تعتمد على عوامل عدة مثل جودة البيانات المقدمة خلال التدريب، والبنية المثالية للشبكة.

وبالتالي فإن هدف البحث: استخدام الشبكات العصبية الاصطناعية كطريقة مكملة لنماذج (إجهاد-تشوه) البيتون المقترحة مسبقاً من خلال إيجاد أهم معاملات النموذج متمثلة بمعامل المرونة E_c ، والإجهاد المحوري عند الذروة f'_c ، والتشوه المحوري الموافق ϵ_{co} ، وذلك لكل خلطة من الخلطات البيتونية المختبرة أو كطريقة بديلة عن نماذج (إجهاد-تشوه) البيتون المعروفة من خلال التنبؤ المباشر بسلوك (إجهاد-تشوه) البيتون المحلي وأهم خصائصه الميكانيكية على الضغط.

يتم عادة قياس معامل المرونة من خلال اختبار العينات الاسطوانية البيتونية تحت تأثير الضغط وذلك بتسجيل منحني (الإجهاد-التشوه) لها، وهذا الاختبار ليس بالأمر السهل تجريبياً؛ إذ يعتبر إجراءه أكثر تعقيداً واستهلاكاً للوقت من الاختبارات الخاصة بإيجاد المقاومة على الضغط. ومع انتشار الشبكات العصبية الاصطناعية (ANNs) Artificial Neural Networks كأدوات حوسبة قوية لإيجاد تنبؤات للمسائل المختلفة، هناك تساؤلات عن مدى استيعابها لقوانين سلوك البيتون وخواصه لتكون بديلاً أو مكملاً للطرق التقليدية القائمة على التحليلات الرياضية الإحصائية، والتي تم على أساسها بناء العديد من النماذج ومعادلات الانحدار الخطية وغير الخطية للتنبؤ بالمسائل المختلفة، وذلك بالاستناد إلى عدد محدود من البيانات، فإذا كانت البيانات الجديدة مختلفة تماماً عن الأصلية، يجب عندها تحديث النموذج ومعاملاته بالإضافة إلى صيغة المعادلة، بينما لا تحتاج الشبكة العصبية الاصطناعية ANN إلى نموذج معادلة محدد، بل تحتاج فقط إلى بيانات كافية كمدخلات ومخرجات، ويمكن إعادة تدريبها عند توفر أي بيانات جديدة؛ بحيث يتم تكيفها بشكل ملائم معها، مما يعد بتنبؤات أكثر دقة وشمولية.

2. الدراسات السابقة

حاول المهندسون والباحثون التعبير عن معامل المرونة كتابع للمقاومة على الضغط لتسهيل التنبؤ به نظرياً، وتعطي الكودات العالمية والدراسات السابقة صيغاً مختلفة للتنبؤ به [1,2,3]. كما اقترحت في الماضي عدة نماذج لعلاقة

عيار الاسمنت في الخلطة الأخرى من اسم معمل البيتون المجلوب.

3. منهجية البحث:



الشكل 1: تحضير العينات.

تنفيذ التجارب: تم إجراء اختبارات الضغط باستخدام جهاز الكسر المخصص لهذا الغرض، يأتي معه أداة لقياس انضغاط البيتون (Compressometer) تثبت في منتصف ارتفاع العينة (التباعد بين حلقتي التثبيت 165 mm)، مع حساسات LVDT عدد/2 من أجل رصد التشوه المحوري والعرضي. اختبرت 3/ أسطوانات كحد أدنى من كل خلطة بيتونية ورسمت منحنيات (إجهاد-تشوه) لها، ومن ثم تم إيجاد المنحنى الوسطي لكل خلطة حيث تم الاكتفاء ببعض النقاط الأساسية لتمثيل كل منحنى كون الجهاز يعطي حدود 3000/ قراءة أي عدد كبير من النقاط عند الاختبار.



الشكل 2: اختبار العينات في مخبر تجريب المواد- جامعة تشرين.

تمت الاختبارات حسب طريقة الاختبار القياسية ASTM C469 [9] لمعامل مرونة البيتون على الضغط، وينص هذا المعيار أن معامل المرونة قابل للتطبيق مع إجهاد تشغيل يتراوح بين (0-40) % من المقاومة القصوى للبيتون وتم حساب معامل المرونة من المعادلة التالية:

$$E = \frac{S_2 - S_1}{\epsilon_2 - 0.000050} \quad (1)$$

المواد الأولية المستخدمة: تنوع الرمل الطبيعي المستخدم في معمل البيتون المجلوب في المنطقة الوسطى بين الرمل القرواني والرمل الحساني والرمل البحري، أما الحصى فمعظمها من مقالع منطقة حسياء (ذات منشأ دولوميتي كلسي)، بقطر أعظمي لا يتجاوز 25mm، وبمعامل لوس أنجلوس للاهتراء متقارب نسبياً بحدود 18%، يمكن تصنيف هذه الحصى وفقاً لأقطارها المختلفة إلى بحص فولي (9.5mm ← 25mm : d)، وبحص عدسي (2.36mm ← 9.5mm : d)، وزرادة أو ما يسمى رمل مكسر (d ≤ 9.5mm)، وذلك وفقاً لتجارب التحليل الحبي التي نُفذت على الإحصارات حسب نسب الخلط التي تعتمدها معمل البيتون المجلوب. بالنسبة للإسمنت فقد تم استخدام اسمنت بورتلاندي عادي صنف I-(32.5 MPa) محلي الصنع إنتاج معمل طرطوس، السطح النوعي له (3150 cm²/g). يوضح الجدول (1) المكونات الأساسية لخلطات مجال المنطقة الوسطى المختبرة. وقد أضيف ملدن Sikament-163 من النوع F (بوليمير عضوي) حسب مواصفات ASTM C494 [8] بنسبة (1) % من محتوى الاسمنت في معظم الخلطات، وتراوح هبوط المخروط بين (10-6) سم. أما إجراءات الصب والمعالجة للعينات فكانت وفق المواصفات السورية، الشكل (1).

جدول 1: كميات المواد بـ (kg) اللازمة لإنتاج متر مكعب واحد من البيتون وذلك لمختلف خلطات.

رقم الخلطة	رمز الخلطة	اسمنت	ماء	ركام خشن	ركام ناعم
1	EN-350	350	200	1106	830
2	ESK-350	370	196	1118	882
3	BAB-350	350	210	930	1020
4	PB-350	350	217	856	942
5	W400	400	216	1020	855
6	BAB-400	400	212	956	995
7	ESK-400	400	200	1132	761
8	EN-400	400	197	1072	740
9	UNI-350	350	175	969	894
10	UNI-400	400	200	971	889
11	Q-425	425	191	995	880
12	F-400	400	200	1219	847
13	PB-450	450	193	996	776

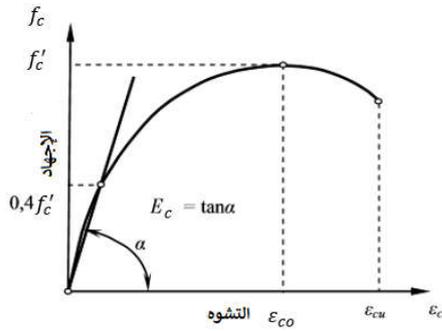
- الركام الخشن (Coarse Aggregate) هو الجزء المحجوز على المنخل (4.75) mm (يشكل البحص الفولي والعدسي معظم الجزء المحجوز بالإضافة إلى جزء بسيط من رمل الكسر)، أما الركام الناعم (Fine Aggregate) أو الرمل فهو المار من المنخل ذاته.

- تم ترميز الخلطات في الجدول 1 كما يلي:

CurveExpert، حيث يكون المنحني خطياً (linear) في البداية، يتشابه قليلاً مع القطع المكافئ (parabola)، ومن المعروف أن المنحني يبدي جزءاً هابطاً بعد الوصول إلى الإجهاد الأقصى (نقطة الذروة)، وتعتبر التتابع الأسية ملائمة نوعاً إذا ماتم إدخال تصحيح عليها (Exponential plus). لذا شكل البحث عن النموذج الأمثل لمنحني (إجهاد-تشوه) البيتون مادة بحثية مهمة لدراسات متتالية استمرت حتى يومنا هذا، ونتيجة التحليل تبين مدى ملاءمة النموذج الموضح بالعلاقة (2) المقترح بالأصل من قبل Popovics [5] والذي تبناه فيما بعد Carreira&Chu [6]، ولكن بعد إدخال تعديل بسيط على المعادلة التي تعطي قيمة معامل المادة Γ والذي يعبر عن هشاشة البيتون ليصبح النموذج المعتمد كالآتي:

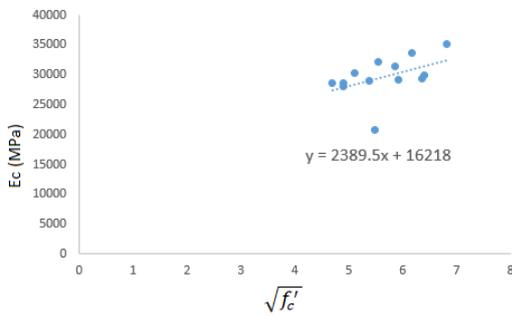
$$\frac{f_c}{f'_c} = \frac{r \left(\frac{\epsilon_c}{\epsilon_{CO}} \right)}{(r-1) + \left(\frac{\epsilon_c}{\epsilon_{CO}} \right)^r} \quad (2)$$

$$r = \frac{1.15 E_c}{1.15 E_c - \frac{f'_c}{\epsilon_{CO}}} \quad (3)$$



الشكل 4: المنحني القياسي لسلوك (إجهاد- تشوه) البيتون الذي يوضح رموز وهيكلية النموذج.

وكما هو معروف غالباً ما يتم التعبير عن معامل مرونة البيتون والتشوه عند الذروة بدلالة المقاومة على الضغط نظراً لكون الاختبارات الخاصة بإيجاد المقاومة أسهل وأقل تعقيداً من الاختبارات الخاصة بإيجاد منحني (إجهاد- تشوه) الذي يعطي قيمها الدقيقة، لذا تم إيجاد معادلات الانحدار الخطي (linear regression) من أجل التنبؤ بالمعاملات (ϵ_{CO} ، E_c) لكل خلطة بيتونية بدلالة المقاومة على الضغط f'_c [يلخص الجدول 2 قيم ϵ_{CO} ، E_c ، f'_c التجريبية للخلطات المختبرة لاستنتاج المعادلات (4)، (5)].



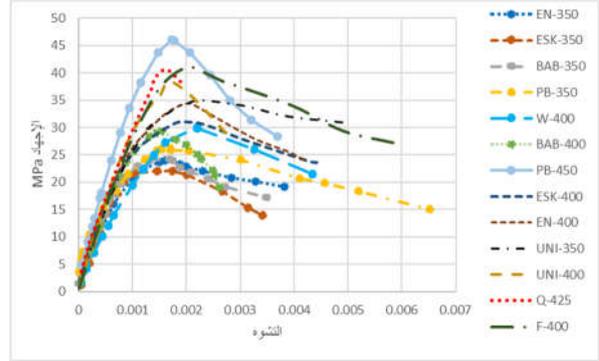
الشكل 5: علاقة معامل المرونة E_c ، reg1.

حيث أن E : معامل المرونة، S_2 : الإجهاد الموافق لـ 40% من الحمولة الحدية.

S_1 : الإجهاد الموافق للتشوه الطولي ϵ_1 ، ϵ_2 : التشوه الطولي الناتج بسبب الإجهاد S_2 .

في هذا السياق نفذت التجارب بعناية، وتم تمثيل منحنيات (الإجهاد- التشوه) للعينات، ومن ثم استنتاج المنحني الوسطي لكل خلطة، الشكل 3.

من المنحني الوسطي لعلاقة (الإجهاد- التشوه) تم استنتاج قيم معامل المرونة E_c ، والإجهاد المحوري عند الذروة f'_c ، والتشوه المحوري الموافق ϵ_{CO} ، وذلك لكل خلطة من الخلطات البيتونية المختبرة، الجدول 2.



الشكل 3: منحنيات (الإجهاد- التشوه) الوسطية للخلطات البيتونية المختبرة.

جدول 2: أهم الخواص الميكانيكية لخلطات المجايل المختبرة حسب منحنيات (إجهاد- تشوه) التجريبية الوسطية.

رقم الخلطة	رمز الخلطة	f_c (MPa)	E_c (MPa)	ϵ_{CO}
1	EN-350	24	28719	0.0016
2	ESK-350	22	28697	0.00175
3	BAB-350	24	28125	0.00169
4	PB-350	26	30253	0.0017
5	W-400	30	20755	0.0022
6	BAB-400	29	28965	0.00156
7	ESK-400	30.8	32201	0.002
8	EN-400	34.4	31515	0.002
9	UNI-350	35	29194	0.0022
10	UNI-400	38	33700	0.00167
11	Q-425	40.5	29400	0.00167
12	F-400	41	29925	0.002
13	PB-450	46.5	35090	0.00173

تمت معالجة المنحني الوسطي لسلوك (إجهاد-تشوه) لكل خلطة من الخلطات على حد، لإيجاد العلاقة الأكثر ملاءمة للبيانات التجريبية باستخدام برنامج

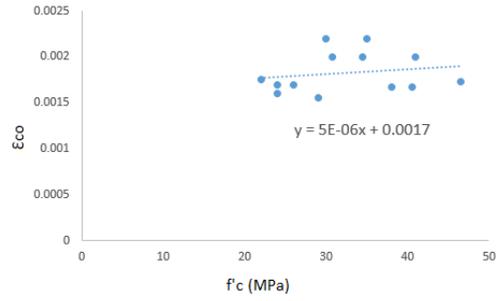
جدول 3: بيانات الشبكات العصبية الاصطناعية المدربة

الشبكة العصبية الاصطناعية	الهدف	بيانات الإدخال	الطبقات المخفية	عدد العصبونات بكل طبقة
Artificial Neural Network	Target	Inputs	Hidden layers	
ANN1	المقاومة على الضغط f'_c	مكونات الخلطة	1:2:3	10:10:10
ANN2	معامل المرونة E_c	مكونات الخلطة	1:2:3:4	9:9:9:9
ANN3	التشوه عند الذروة ϵ_{co}	مكونات الخلطة، f'_c	1:2	10:5
ANN4	E_c	f'_c	1:2	30:10
ANN5	الإجهاد المقابل للتشوه f'_c	قيم التشوه من المنحنيات f'_c	1:2	10:5

ملاحظة: تتمثل مكونات الخلطة في الجدول (3) بكميات الاسمنت، الماء، الركام الخشن، الركام الناعم (الرمال) الموضحة في الجدول (1) واللازمة لإنتاج متر مكعب واحد من البتون.

هيكلية الشبكات المستخدمة مع عدد الطبقات المخفية وعدد العصبونات المستخدمة في كل طبقة موضحة في الجدول (3)، وفي جميعها تحتوي طبقة المخرجات على عصبون واحد (1) يخزن قيمة مقاومة البتون على الضغط، أو معامل المرونة، أو التشوه عند الذروة، أو الإجهاد المقابل للتشوه في منحنيات (الإجهاد-التشوه) للخلطات المختبرة؛ وذلك حسب ما درّبت عليه الشبكة العصبية المصممة. تم تدريب الشبكة العصبية باستخدام جزء (70%) من البيانات التجريبية المتاحة، واستخدم الجزء الآخر لكل من التحقق (15% Validation)، والاختبار (15% Test)، وأخيراً تتم مقارنة كل البيانات التجريبية المستهدفة (All) مع خرج الشبكة (output)، حيث يتم التوقف عن التدريب عند الوصول إلى قيمة صغيرة للخطأ بين البيانات التجريبية المستهدفة (Target) وخرج الشبكة (output). يتم الحكم على قيمة الخطأ وحسن تدريب الشبكة من خلال قيمة معامل الارتباط R للانحدار الخطي بين خرج الشبكة والهدف، الأشكال 9-7، 11، (a).

تحليل النتائج: لبيان مدى ملاءمة خرج الشبكات العصبية الاصطناعية (ANN output) للبيانات التجريبية المستهدفة (Target) تم رسم الانحدار الخطي لها، الأشكال 9-7، 11، (a). بالإضافة إلى التمثيل البياني لخرج الشبكات العصبية الاصطناعية مقابل البيانات التجريبية المستهدفة لكل خلطة، حيث يمثل الإحداثي السيني فيها رقم الخلطة، والإحداثي العيني قيمة المقاومة على الضغط أو معامل المرونة أو التشوه عند الذروة أو الإجهاد المقابل للتشوه في المنحني، وذلك حسب ما درّبت عليه كل شبكة، الأشكال 9-7، 11، (b).

الشكل 6: علاقة التشوه عند الذروة ϵ_{co} ، $reg2$.

يوضح الشكل 5 معادلة الانحدار الخطي الخاصة بالتنبؤ بمعامل المرونة بدلالة الجذر التربيعي للمقاومة على الضغط $reg1$ ، وبعد التقريب لصيغة صحيحة مبسطة تصبح كالآتي:

$$E_c = 2400\sqrt{f'_c} + 16000 \quad (MPa) \quad (4)$$

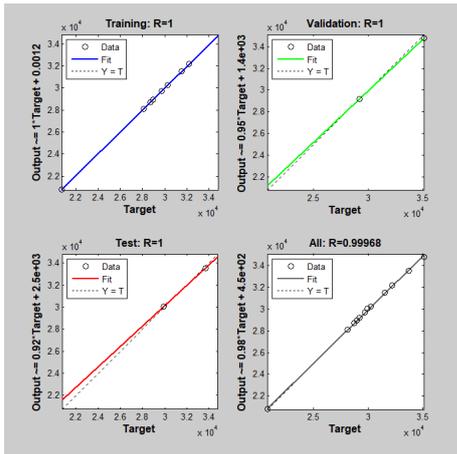
يوضح الشكل 6 معادلة الانحدار الخطي بين قيمة التشوه عند الذروة والمقاومة على الضغط $reg2$:

$$\epsilon_{co} = 5 \times 10^{-6} f'_c + 0.0017 \quad (5)$$

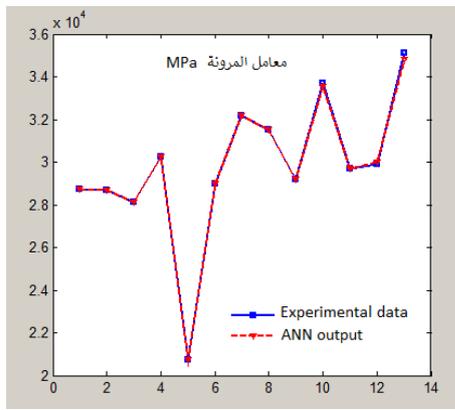
حيث أن: f'_c تؤخذ بـ (MPa).

الشبكات العصبية الاصطناعية المستخدمة: استُخدمت شبكات عصبية ذات تغذية أمامية مع تقنية انتشار عكسي Feedforward back prop ANNs، تتكون الشبكات العصبية المستخدمة في هذه الدراسة من عدد من عناصر المعالجة المترابطة (العصبونات الاصطناعية أو الخلايا العصبية الاصطناعية) التي تكون مرتبة في طبقات، والتفاعل بينها قائم على الأوزان، تحدد مصفوفة الوزن التأثير بين العناصر المترابطة من طبقة إلى أخرى، والتي تقابل كثافة الإشارة المراد إرسالها. توجد في كل شبكة طبقة مدخلات حيث يتم إدخال البيانات على الشبكة Inputs، وطبقة مخرجات حيث يتم تخزين الإجابة على المسألة المراد حلها (الهدف) Target، بينهما طبقات مخفية Hidden layers تقوم بالربط بينهما واستخلاص الميزات المفيدة من بيانات الإدخال للتنبؤ بخرج الشبكة Outputs. يعتبر العدد الأمثل للطبقات المخفية وعدد الخلايا العصبية في كل طبقة مخفية غير محدد. ولذلك ينبغي إجراء التجربة لاختبار عدد كاف من الطبقات المخفية وعدد الخلايا العصبية في كل طبقة مخفية [10، 11]. كل خلية عصبية لديها أيضا تابع تفعيل يحدد ويرسل قيم التحفيز إلى الخلايا العصبية للطبقة اللاحقة، يعتبر تابع سيمغويد tan-sigmoid واحداً من أكثر توابع التفعيل استخداماً في هذه العملية [7]. يتم تحديد التغيرات في الوزن بين الطبقات باستخدام خوارزمية تنازلية متدرجة gradient descent method حيث ينتشر الخطأ في الاتجاه المعاكس وهو إجراء منهجي لتعديل مصفوفة الأوزان بحيث يتم تقليل الخطأ التربيعي إلى نطاق مقبول. ويتم الحكم على حسن هيكلية وتام تدريب الشبكة من خلال قيم معامل الارتباط R بين خرج الشبكة والبيانات التجريبية المستهدفة.

i. التنبؤ بالمقاومة على الضغط اعتماداً على المكونات الرئيسية للخلطة:



(a)



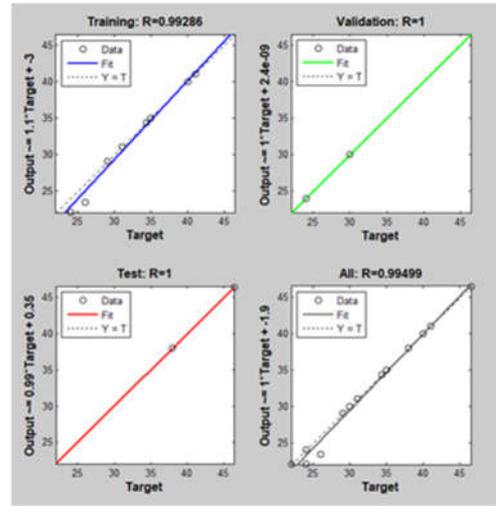
(b)

الشكل 8: الانحدار الخطي والتمثيل البياني لخرج ANN2 مع البيانات التجريبية.

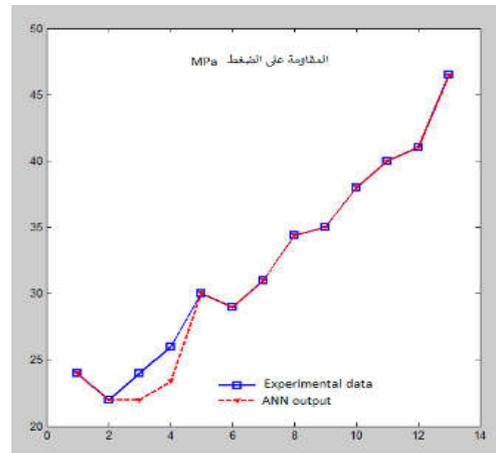
بلاحظ من الشكل 8، (b) التقارب الكبير بين البيانات التجريبية وخرج الشبكة حتى أنها تنطبق تقريباً. وهذا التقارب توضحه قيمة معامل الارتباط بين قيم البيانات التجريبية المستهدفة (Target) وخرج الشبكة output، الشكل 8، (a). مما يدل على كفاءة الشبكة في التنبؤ بمعامل المرونة إذا ماتم التدريب بإدخال مكونات الخلطة بالإضافة للمقاومة على الضغط.

iii. التنبؤ بمعامل المرونة بدلالة المقاومة على الضغط فقط:

لدراسة إمكانية الشبكات العصبية الاصطناعية على التنبؤ بمعامل مرونة البيتون بدلالة المقاومة على الضغط فقط، في حال لم تتوفر معلومات عن مكونات الخلطة البيتونية مثلاً، تم بناء الشبكة ANN4 بحيث تتضمن طبقة المدخلات المقاومة على الضغط لكل خلطة من الخلطات، أما طبقة المخرجات المستهدفة فكانت قيم معامل المرونة التجريبية المقابلة لكل خلطة منها.



(a)



(b)

الشكل 7: الانحدار الخطي والتمثيل البياني لخرج ANN1 مع البيانات التجريبية.

يوضح الجدول (4) – في الملحق A- نسبة الخطأ بين القيم التجريبية وخرج الشبكات العصبية الاصطناعية ANN1 عند التنبؤ بالمقاومة على الضغط.

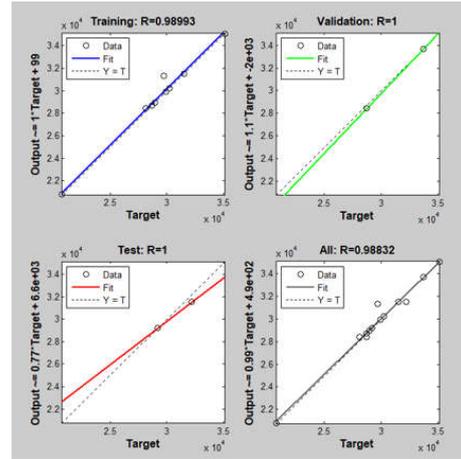
تعتبر نسبة الخطأ مهمة بالنسبة لمعظم الخلطات، بينما بلغت قيمتها 8.33%، 9.99% عند التنبؤ بالمقاومة على الضغط للخلطتين رقم 3، 4 كما هو مبين في الشكل 7، (b) واللتين تمثلان الخلطتين (BAB-350)، (PB-350) على التوالي حيث أن الإحداثي السيني في الشكل 7، (b) يمثل رقم الخلطة، يوافق رمز الخلطة الموضح في الجدول 2، حيث تمت المحافظة على نفس ترتيب الخلطات في كل الشبكات المدربة.

ii. التنبؤ بمعامل المرونة بدلالة مكونات الخلطة والمقاومة على الضغط:

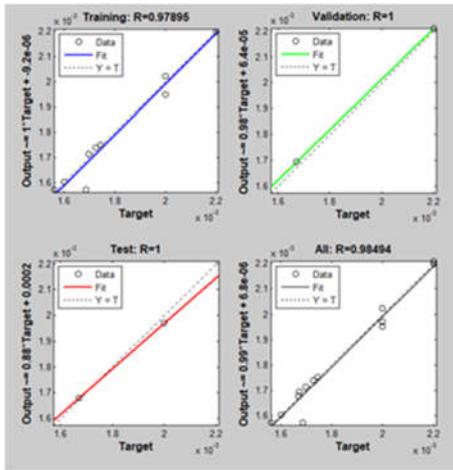


الشكل 10: النسبة المنوية للخطأ عند التنبؤ بمعامل المرونة.

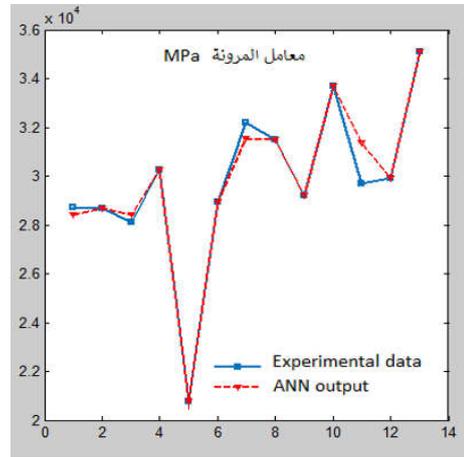
iv. التنبؤ بالتشوه عند الذروة بدلالة مكونات الخلطة والمقاومة على الضغط:



(a)



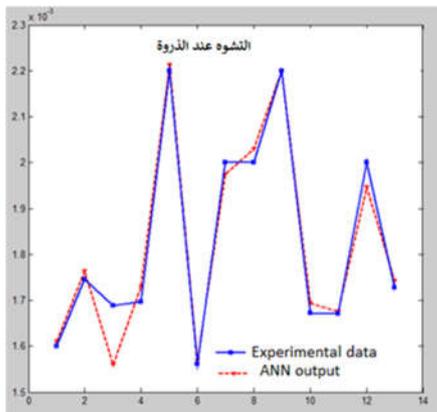
(a)



(b)

الشكل 9: الانحدار الخطي والتمثيل البياني لخرج ANN4 مع البيانات التجريبية.

يوضح الجدول (5)- في الملحق A- نسبة الخطأ بين القيم التجريبية وخرج الشبكات العصبية الاصطناعية ANN4، ANN2 الخاصة بالتنبؤ بمعامل المرونة، والقيم النظرية المحسوبة من العلاقة reg1 (4)، حيث لم تتجاوز نسبة الخطأ 0.78% عند التنبؤ بمعامل المرونة استناداً إلى (مكونات الخلطة، f'_c) باستخدام ANN2، مما يدل على كفاءة هذه الشبكة بالمقارنة مع ANN4 التي استندت إلى قيم f'_c فقط، والتي ارتفعت نسبة الخطأ فيها حتى 5.58%. كما وصلت نسبة الخطأ عند التنبؤ بمعامل المرونة بدلالة المقاومة على الضغط باستخدام العلاقة reg1 حتى 40.426%، مما يظهر تفوق الشبكات العصبية الاصطناعية على العلاقات النظرية التي تعطي معامل المرونة استناداً إلى المقاومة على الضغط كما في العلاقة reg1 (4).



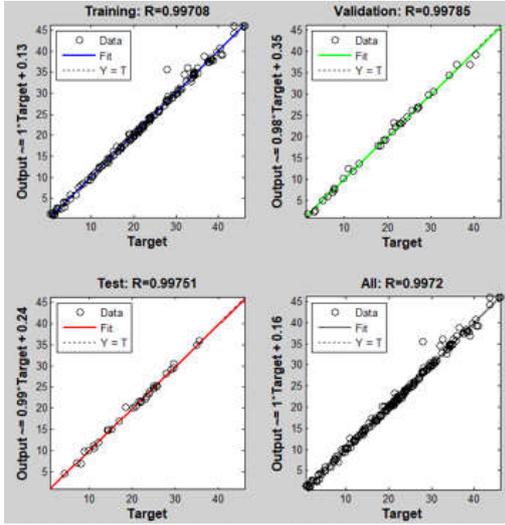
(b)

الشكل 11: الانحدار الخطي (a) والتمثيل البياني لخرج ANN3 مع البيانات التجريبية.

يوضح الجدول (6)- في الملحق A- نسبة الخطأ بين القيم التجريبية (Exp) وخرج الشبكة العصبية الاصطناعية ANN3، وعلاقة الانحدار الخطي reg2 (5) للتنبؤ بالتشوه عند الذروة ϵ_{CO} نظرياً استناداً إلى المقاومة على الضغط.

حيث يمثل محور السينات رقم النقاط التي تمثل كامل منحنيات (إجهاد-تشوه) للخلطات المختبرة.

يوضح الجدول (7) - في الملحق A - نسبة الخطأ بين قيم الإجهاد التجريبي المستهدف والقيم التي تنتجها ANN5 (خرج الشبكة) عند كل قيمة للتشوه، ويلاحظ أن نسبة الخطأ كانت صغيرة عند معظم النقاط ما عدا عدد محدود منها فقد وصلت أكبر نسبة للخطأ حتى 22.8%.



الشكل 12: مقارنة النسبة المئوية للخطأ عند التنبؤ بالتشوه عند الذروة باستخدام ANN3، reg2.

لم تتجاوز نسبة الخطأ 7.62% عند التنبؤ بالتشوه عند الذروة بدلالة مكونات الخلطة والمقاومة على الضغط باستخدام ANN3، بينما ارتفعت نسبة الخطأ حتى 18.19% عند التنبؤ بالتشوه عند الذروة بدلالة المقاومة على الضغط فقط في معادلة الانحدار الخطي reg2.

v. التنبؤ بمنحني (الإجهاد-التشوه) مباشرة استناداً إلى المقاومة القصوى على الضغط :

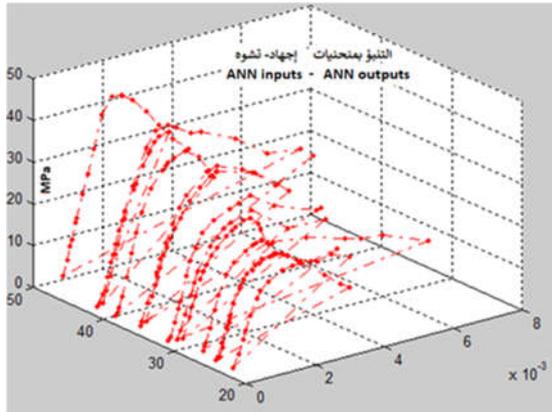
بعد رسم المنحنيات الوسطية التجريبية التي تمثل علاقة (إجهاد-تشوه) البيتون لكل خلطة من الخلطات المختبرة، كما هو موضح في الشكل (3)، تم تدريب شبكة عصبية إصطناعية ANN5 على قيم التشوه والإجهاد المقابل لعدة نقاط من كل منحنى من هذه المنحنيات التجريبية 13/ خلطة بيتونية تُمثل بـ 13 منحنيًا لعلاقة إجهاد-تشوه/.

من أجل كل منحنى تكون المدخلات إلى الشبكة عبارة عن التشوه المحوري المقاس لكل نقطة مع المقاومة على الضغط لبيتون الخلطة التي يمثلها المنحنى.

أما الهدف الذي يتم تدريب الشبكة عليه فهو القيم التجريبية للإجهاد المطبق f_c المقابل لكل قيمة مُدخلة للتشوه المحوري ϵ_c .

بلغ عدد النقاط التي تم التدريب عليها 217/ نقطة، مأخوذة من منحنيات (إجهاد-تشوه) الوسطية التجريبية للخلطات المختبرة وذلك لدراسة إمكانية استخدام الشبكات العصبية الاصطناعية كبديل عن النماذج الرياضية الخاصة بالتنبؤ بالمنحني.

الشكل 14: الانحدار الخطي لخرج ANN5 مع البيانات التجريبية.

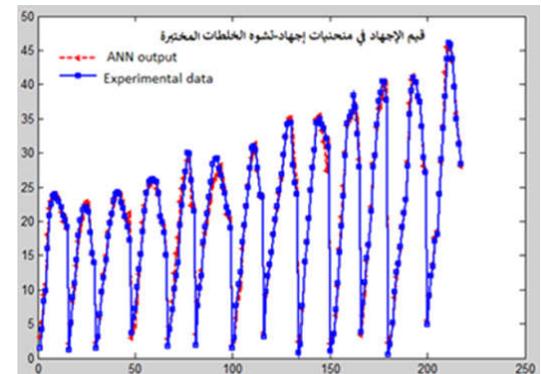


الشكل 15: التمثيل البياني الفراغي لخرج ANN5 مع المدخلات.

تم تمثيل البيانات التجريبية مع خرج الشبكة ANN5 الخاصة بالتنبؤ المباشر بمنحني (إجهاد-تشوه) وتم إيجاد قيمة R^2 للانحدار الخطي بينهما ($R^2 = 0.9944$) كما في الشكل 16(a).

وبنفس الأسلوب تم تمثيل البيانات التجريبية مع بيانات النموذج النظري لعلاقة (إجهاد-تشوه) البيتون الذي تعطيه العلاقات (2)، (3) أي قيم الإجهاد النظرية وذلك بعد تعويض قيم معامل المرونة والتشوه عند الذروة للخلطات المختلفة كما تعطيها ANN2، ANN3، ثم تم إيجاد قيمة R^2 للانحدار الخطي بينهما ($R^2 = 0.9765$) كما في الشكل 16(a).

ونتيجة لقيم R^2 المقاربة نسبياً بين الحالتين تبين إمكانية استخدام الشبكات العصبية الاصطناعية سواء كطريقة مكملة للنموذج النظري لعلاقة (إجهاد-تشوه) البيتون من خلال التنبؤ بأهم معاملات النموذج كما في الشبكات (ANN2، ANN3)، أو كطريقة بديلة لنماذج (إجهاد-تشوه) النظرية من خلال التنبؤ بنقاط المنحني مباشرة كما في



الشكل 13: التمثيل البياني لخرج ANN5 مع البيانات التجريبية.

يوضح التمثيل البياني في الشكل 13 قيمة الإجهاد الذي تنتجها الشبكة مع قيمة الإجهاد التجريبي المستهدف عند كل نقطة.

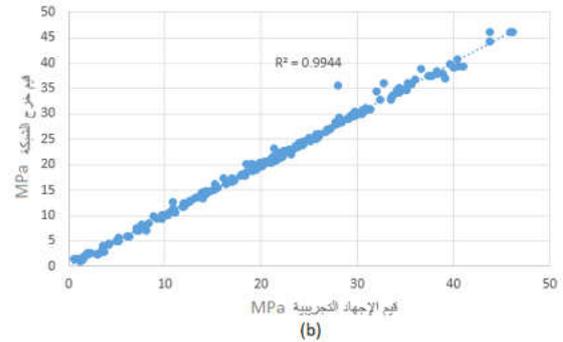
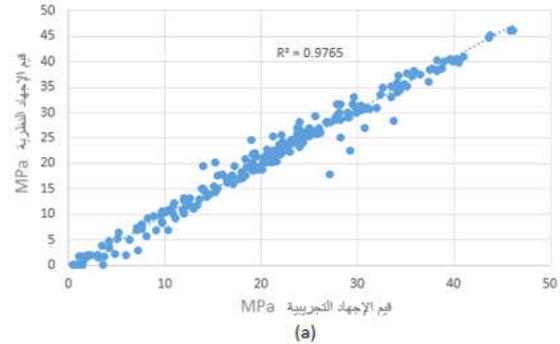
محلية من معظم المقالع السورية وبنسب خلط مختلفة، لتوسيع قاعدة البيانات في الشبكات العصبية الاصطناعية المدربة مما يجعلها تعد بتنبؤات أكثر دقة وشمولية.

2. يمكن إدخال تأثير معاملات أخرى بالإضافة إلى المكونات الرئيسية للخلطة كالحجم الأكبر للحصويات، أو هبوط المخروط، وغيرها من العوامل المؤثرة عند توفر بيانات إضافية، وذلك من أجل تنبؤ أفضل بالخصائص الميكانيكية للخلطات البيتونية باستخدام الشبكات العصبية الاصطناعية.

المصادر

- [1] Bajza, A.; Rouseková, I. (2006). *Technológia betónu*. Bratislava: JAGA GROUP, s.r.o. 190 s. ISBN 80-8076-032-2.
- [2] Noguchi, T.; Tomosawa, F.; Nemati, K. M.; et al. (2009). Practical Equation for Elastic Modulus of Concrete. *ACI Structural Journal: Technical paper*, vol. 106, no. 5, p. 690-696.
- [3] Yan, K.; Shi, C. (2010). Prediction of elastic modulus of normal and high strength concrete by support vector machine. *Construction and Buildings Materials (online)*. Elsevier. Vol. 24, issue 8, p. 1479–1485.
- [4] Hognestad, E. (1951). A Study of Combined Bending and Axial Load in R.C. Members, *Bulletin 339, Engineering Experiment Station, University of Illinois, Urbana*.
- [5] Popovics, S. (1973). "A numerical approach to the complete stress-strain curves for concrete", *Cement and Concrete Research*, Vol. 3, No. 5, pp. 583-599.
- [6] Carreira, DJ & Chu, KH. (1985). 'Stress-Strain Relationship for plain concrete in compression', *Journal of the American Concrete Institute*, vol. 82 no. 6, pp. 797-804.
- [7] Moretti, José Fernando; Minussi, Carlos Roberto; Akasaki, Jorge Luis; Fioriti, Cesar Fabiano; Pinheiro Melges, José Luiz; Mitsuuchi Tashima, Mauro. (2016) "Prediction of modulus of elasticity and compressive strength of concrete specimens by means of artificial neural networks". *Acta Scientiarum. Technology*, vol. 38, núm. 1, enero-marzo, pp. 65-70 Universidade Estadual de Maringá Maringá, Brasil.
- [8] ASTM C 494 "Standard Specification for Chemical Admixtures for Concrete"
- [9] ASTM C 469-94" Standard Test Method for Static Modulus of Elasticity and Poisson's Ratio of Concrete in Compression"
- [10] Salim T. Yousif. (2007). "Artificial Neural Network Modeling of Elasto-Plastic Plates", Ph.D. thesis, University of Mosul, Iraq, pp. 1-198.
- [11] Jung, S. and Ghaboussi, J., (2006) "Neural Network Constitutive Model for Rate-Dependent Materials", *Computers and Structures*, Vol. 84, pp 995-963.

الشبكات ANN5 حيث تعطي الشبكة قيمة الإجهاد المقابل لأي تشوه معطى إذا ما علمت مقاومة البيتون.



الشكل 16: الانحدار الخطي للبيانات النظرية لنموذج (إجهاد-تشوه) المقترح مع البيانات التجريبية (a)، الانحدار الخطي لخرج الشبكة ANN5 مع البيانات التجريبية (b).

4. الاستنتاجات والتوصيات

4.1 الاستنتاجات

تم استيعاب قوانين سلوك البيتون بشكل جيد من قبل الشبكات العصبية الاصطناعية.

دقة الشبكات العصبية الاصطناعية في التنبؤ بخصائص البيتون.

إمكانية استخدام الشبكات العصبية الاصطناعية كطريقة بديلة عن النماذج الرياضية المتوفرة للتنبؤ مباشرة بمنحني (إجهاد- تشوه) مختلف العينات البيتونية التي تم تحضيرها باستخدام مواد محلية وبنسب خلط مختلفة، أو كطريقة مكملة من خلال التنبؤ بأهم معاملات نماذج (إجهاد-تشوه) المتوفرة.

قدرة الشبكات العصبية الاصطناعية على التنبؤ بالمقاومة على الضغط بدلالة مكونات الخلطة، ويمكن توسيع المدخلات لتشمل إضافات ومواصفات أخرى.

تم ربط معامل المرونة والتشوه عند الذروة بالمقاومة على الضغط، وذلك في معظم العلاقات المتوفرة في المراجع، علماً أنها تتعلق أيضاً بالمواد الداخلة في تركيب الخلطة البيتونية بدرجة كبيرة لا يجوز إهمالها. حيث تفوقت الشبكات العصبية الاصطناعية على معادلات الانحدار الخطي الخاصة بالتنبؤ بها بشكل كبير.

4.2 التوصيات

1. الاحتفاظ ببنك معلومات لنتائج وبيانات جميع العينات البيتونية المختبرة (على جهاز الاختبار المستخدم) والمحضرة من مواد

الملحق A : الجداول (4)، (5)، (6)، (7):

الجدول 4: نسبة الخطأ بين القيم التجريبية (Exp) وخرج الشبكات العصبية الاصطناعية ANN1 عند التنبؤ بالمقاومة على الضغط.

رقم الخلطة	رمز الخلطة	Exp-fc	ANN1	Error%
1	EN-350	24	24	-9.9E-09
2	ESK-350	22	22.00001	-4.1E-05
3	BAB-350	24	22.00024	8.332349
4	PB-350	26	23.40157	9.993948
5	W-400	30	30	-7.9E-09
6	BAB-400	29	29	-8.6E-09
7	ESK-400	30.8	30.9976	0.00778
8	EN-400	34.4	34.4	-1.3E-08
9	UNI-350	35	35	-1.1E-08
10	UNI-400	38	38	-4.1E-09
11	Q-425	40.5	40	-4.4E-09
12	F-400	41	41	-4.3E-09
13	PB-450	46.5	46.42081	0.170307

الجدول 5: نسبة الخطأ بين القيم التجريبية (Exp) وخرج الشبكات العصبية الاصطناعية ANN2، ANN4 وعلاقة الانحدار الخطي regl الخاصة بالتنبؤ بمعامل المرونة E_c .

رقم الخلطة	رمز الخلطة	Exp-Ec	ANN2	Error%	ANN4	Error%	regl	Error%
1	EN-350	28719	28719	6.126E-10	28422	1.03416	27757.6	3.34778
2	ESK-350	28697	28697	-1.241E-09	28697	-9E-08	27257	5.01795
3	BAB-350	28125	28125	2.434E-09	28422	-1.056	27757.6	1.30649
4	PB-350	30253	30253	-1.516E-08	30253	-1E-07	28237.6	6.66166
5	W-400	20755	20755	-1.59E-07	20755	-5E-06	29145.3	-40.426
6	BAB-400	28965	28965	-7.719E-10	28965	-4E-08	28924.4	0.14018
7	ESK-400	32201	32201	9.127E-09	31519	2.11793	29319.5	8.94861
8	EN-400	31515	31515	1.104E-08	31515	1.6E-07	30076.4	4.56493
9	UNI-350	29194	29172.6	0.0732857	29194	1.5E-07	30198.6	-3.4411
10	UNI-400	33700	33556.4	0.426229	33691.6	0.02492	30794.6	8.62138
11	Q-425	29400	29703	1.178E-08	31345	-5.5852	31273.5	-6.3725
12	F-400	29925	29977.9	-0.1800934	29925	-2E-08	31367.5	-4.8204
13	PB-450	35090	34814.3	0.7858146	35095	4.8E-05	32365.8	7.76341

الجدول 6: نسبة الخطأ بين القيم التجريبية (Exp) وخرج الشبكة العصبية الاصطناعية ANN3، وعلاقة الانحدار الخطي reg2 للتنبؤ بالتشوه عند الذروة ε_{co} .

رقم الخلطة	رمز الخلطة	Exp- ε_0	ANN3	Error%	reg2	Error%
1	EN-350	0.0016	0.001611	-0.67501	0.00182	-13.75
2	ESK-350	0.001745	0.001764	-1.09978	0.00181	-3.72493
3	BAB-350	0.001688	0.001559	7.628172	0.00182	-7.81991
4	PB-350	0.001697	0.00173	-1.93368	0.00183	-7.83736
5	W-400	0.0022	0.002212	-0.55707	0.00185	15.90909
6	BAB-400	0.001561	0.001569	-0.52837	0.001845	-18.1935
7	ESK-400	0.002	0.001974	1.298274	0.001854	7.3
8	EN-400	0.002	0.00203	-1.48315	0.001872	6.4
9	UNI-350	0.0022	0.0022	0.018575	0.001875	14.77273
10	UNI-400	0.001673	0.001693	-1.18079	0.00189	-12.9707
11	Q-425	0.001671	0.001675	-0.34648	0.001903	-13.854
12	F-400	0.002	0.001947	2.664865	0.001905	4.75
13	PB-450	0.001727	0.001742	-0.85612	0.001933	-11.8992

الجدول 7: نسبة الخطأ بين القيم التجريبية (Exp) وخرج الشبكة العصبية الاصطناعية ANN5.

النسبة المئوية للخطأ بين	خرج الشبكة Outputs	الإجهاد التجريبي المستهدف Target	مدخلات الشبكة (Inputs)		رمز الخلطة	رقم النقطة
			التشوه ε_c	مقاومة بيتون الخلطة f'_c		
Error %	ANN5	Exp- f_c	ε_c	مقاومة بيتون الخلطة f'_c	EN-350	1
-5.0182	1.5682	1.493264	5.15E-05	24		2
-9.44066	4.571321	4.176986	0.000145	24		3
-4.19418	8.598988	8.252849	0.000285	24		4
-3.33781	10.08674	9.76094	0.000339	24		5
-8.14222	17.31868	16.01472	0.000658	24		6
-0.75268	20.97417	20.81748	0.001	24		7
-0.74629	22.66357	22.49569	0.001209	24		8
-1.71225	24.09461	23.689	0.001512	24		9
0.310579	23.92546	24	0.0016	24		10
2.340362	22.70676	23.25092	0.001882	24		11
1.315784	22.54519	22.84579	0.002	24		12
2.027415	21.66365	22.11195	0.0023	24		

1.782798	20.47161	20.84321	0.002842	24		13	
1.601727	19.77272	20.09458	0.003294	24		14	
-0.21568	19.1412	19.1	0.003814	24		15	
10.27538	1.00671	1.121999	5.15E-05	22		16	
4.257005	4.935691	5.155146	0.0002	22		17	
-12.214	9.944035	8.86167	0.000321	22		18	
-15.7604	12.58376	10.87052	0.000397	22		19	
-3.56033	14.85581	14.34508	0.000524	22		20	
-0.42813	17.99886	17.92213	0.000715	22		21	
-0.23318	20.1385	20.09165	0.000842	22		22	
0.009955	21.59247	21.59462	0.001045	22	ESK-350	23	
2.718677	21.39995	21.998	0.001464	22		24	
-1.9823	22.43611	22	0.001745	22		25	
-9.05219	23.30246	21.36818	0.002012	22		26	
2.851029	17.79797	18.32029	0.00267	22		27	
-6.33984	16.22339	15.25617	0.003152	22		28	
0.147089	13.97941	14	0.00342	22		29	
14.59106	1.263134	1.478925	3.03E-06	24		BAB-350	30
4.6727	2.8956	3.037538	5.15E-05	24			31
6.805688	5.925732	6.35847	0.00017	24			32
3.299048	9.365751	9.685273	0.000288	24	33		
-0.08989	11.81816	11.80755	0.000382	24	34		
-0.57242	14.396	14.31406	0.000491	24	35		
-0.29833	17.83255	17.7795	0.00067	24	36		
1.121063	19.42805	19.64832	0.000785	24	37		
3.238417	20.40356	21.08642	0.000879	24	38		
3.996699	22.14317	23.06501	0.0011	24	39		
0.75014	23.77034	23.95	0.001315	24	40		
0.005152	24.19875	24.2	0.001688	24	41		
0.221469	23.90694	23.96	0.001739	24	42		
-1.09102	23.04772	22.79898	0.001879	24	43		
-2.3674	22.386	21.86829	0.002076	24	44		
0.013474	20.64863	20.65142	0.002409	24	45		
-5.64499	20.19434	19.11528	0.002715	24	46		
1.479261	16.97087	17.22568	0.003489	24	47		

-8.90036	3.923047	3.602418	3.03E-06	26	PB-350	48
0.575508	5.963594	5.998114	5.45E-05	26		49
3.714256	6.990974	7.260653	8.18E-05	26		50
-1.41113	10.54542	10.39868	0.0002	26		51
-2.34624	13.32455	13.01909	0.000336	26		52
0.106919	15.182	15.19825	0.000452	26		53
0.264068	18.44346	18.49229	0.000688	26		54
1.414354	21.13811	21.44136	0.000918	26		55
0.570413	23.93242	24.06972	0.00123	26		56
2.221985	25.23048	25.80384	0.001448	26		57
1.496638	25.5917	25.98053	0.001533	26		58
0.082984	26.07834	26.1	0.001697	26		59
-0.80232	26.10377	25.896	0.001709	26		60
-1.30351	26.08035	25.74476	0.002045	26		61
-0.1054	24.07895	24.0536	0.003003	26		62
-0.20999	20.72262	20.6792	0.0041	26		63
-3.14973	20.42423	19.80056	0.004567	26		64
-9.67198	20.18582	18.40563	0.005194	26		65
-0.22741	15.13563	15.10129	0.006518	26		66
-13.9736	1.902354	1.669119	5.15E-05	30		W-400
0.423374	4.180488	4.198263	0.000145	30	68	
-5.70276	7.523553	7.11765	0.000285	30	69	
-1.53392	10.19516	10.04114	0.000436	30	70	
0.966332	11.86818	11.98399	0.000548	30	71	
3.702995	13.48392	14.00243	0.000658	30	72	
0.983365	19.26249	19.45379	0.001	30	73	
-1.72305	22.68592	22.30165	0.0012	30	74	
-1.48905	25.34398	24.97213	0.0014	30	75	
0.477711	27.10886	27.23898	0.0016	30	76	
0.69121	29.79264	30	0.002191	30	77	
0.240388	29.84368	29.9156	0.002212	30	78	
1.206864	25.68979	26.00362	0.003261	30	79	
2.581444	20.97528	21.5311	0.004333	30	80	
-13.4682	2.1536	1.897976	5.76E-05	29	BAB-400	81
0.465898	7.570697	7.606134	0.000242	29		82

1.970642	10.09315	10.29605	0.000327	29		83
-4.04827	12.47749	11.99202	0.000406	29		84
-0.12821	16.99611	16.97435	0.000567	29		85
-0.73911	19.23813	19.09698	0.000661	29		86
-0.12474	21.16908	21.14271	0.000755	29		87
0.231493	23.56055	23.61522	0.000894	29		88
0.241736	25.6669	25.72909	0.001045	29		89
0.093076	28.2911	28.31745	0.001315	29		90
0.143014	28.94854	28.99	0.001464	29		91
0.72098	28.98947	29.2	0.001561	29		92
-0.57913	27.89412	27.73351	0.001803	29		93
1.219632	26.42512	26.75139	0.002	29		94
1.37547	24.70253	25.04704	0.002221	29		95
0.208162	24.11463	24.16493	0.002291	29		96
0.266851	22.05619	22.1152	0.002494	29		97
-1.76093	21.56963	21.19638	0.002533	29		98
-6.56537	20.24742	19	0.002628	29		99
5.039226	1.384481	1.457951	3.03E-06	30.8		100
14.42939	2.533057	2.960196	5.24E-05	30.8		101
-2.84986	7.876305	7.658061	0.0002	30.8		102
-3.20084	11.18683	10.83987	0.000298	30.8		103
-1.10691	12.6893	12.55038	0.00035	30.8		104
1.82876	16.69644	17.00746	0.000519	30.8		105
2.178215	19.07165	19.49632	0.000636	30.8		106
2.630997	21.65642	22.2416	0.000779	30.8		107
0.617951	24.81522	24.96952	0.000982	30.8	ESK-400	108
-2.10925	28.37197	27.7859	0.0013	30.8		109
0.282094	30.6431	30.72978	0.001782	30.8		110
0.880259	30.72712	31	0.00203	30.8		111
1.245206	30.04218	30.42098	0.002379	30.8		112
-1.82699	28.28827	27.78072	0.00307	30.8		113
1.669169	23.3739	23.77067	0.0043	30.8		114
-0.51701	23.72201	23.6	0.004427	30.8		115
14.66234	2.688754	3.150724	5.15E-05	34.4	EN-400	116
2.714969	9.425724	9.688771	0.000242	34.4		117

-0.1861	12.0463	12.02393	0.000327	34.4		118
0.189364	13.63015	13.65601	0.000385	34.4		119
0.558204	15.39632	15.48274	0.000455	34.4		120
0.08286	18.00414	18.01907	0.000567	34.4		121
1.150034	20.03301	20.26608	0.000661	34.4		122
1.236539	21.94035	22.21504	0.000755	34.4		123
-0.05506	24.53868	24.52517	0.000894	34.4		124
-0.24564	26.9701	26.90401	0.001042	34.4		125
-2.59555	30.46056	29.68994	0.001315	34.4		126
-1.20127	32.80567	32.41626	0.0016	34.4		127
0.167575	34.06294	34.12011	0.001906	34.4		128
0.305568	34.29488	34.4	0.002073	34.4		129
0.183026	34.30703	34.36994	0.0021	34.4		130
-0.85961	28.46122	28.21865	0.003209	34.4		131
2.555263	25.00919	25.665	0.00387	34.4		132
-1.18009	24.28322	24	0.004194	34.4		133
-10.3519	0.83254	0.75444	3.03E-06	35		134
-12.909	2.18144	1.932019	5.15E-05	35		135
-9.34159	8.28592	7.578012	0.000227	35		136
-5.18946	14.87438	14.14056	0.00047	35		137
-2.74574	17.43238	16.96652	0.000582	35		138
-1.2115	20.60851	20.36182	0.00073	35		139
-0.65354	24.66804	24.50787	0.000939	35		140
-0.99562	28.13799	27.8606	0.001152	35		141
-0.8739	30.7093	30.44326	0.001352	35		142
-0.34743	34.50532	34.38586	0.001936	35	UNI-350	143
-0.99551	34.62808	34.28675	0.002	35		144
0.923768	34.67668	35	0.002242	35		145
-1.83544	34.80548	34.17816	0.002952	35		146
2.500881	32.67914	33.51737	0.00327	35		147
-7.84873	34.52584	32.01321	0.003906	35		148
-1.15896	31.16756	30.81048	0.005015	35		149
-11.81588	1.19852	1.071869	3.03E-06	38		150
-10.7377	2.609851	2.356787	5.15E-05	38	UNI-400	151
-15.7269	4.066441	3.513825	0.0001	38		152

-1.59478	7.159402	7.047018	0.000191	38		153
-2.33615	11.19141	10.93593	0.000315	38		154
0.348087	15.42643	15.48032	0.000461	38		155
0.817992	19.17016	19.32827	0.000597	38		156
1.525334	23.37853	23.74066	0.000758	38		157
0.510507	29.46532	29.61651	0.001021	38		158
-2.02667	35.0019	34.30662	0.001355	38		159
-2.52279	36.0705	35.18291	0.001445	38		160
-2.43391	36.8249	35.94991	0.001521	38		161
1.098699	37.9781	38.4	0.001673	38		162
-6.17357	38.81972	36.56251	0.002001	38		163
-10.5023	36.12814	32.69445	0.002396	38		164
-12.6786	31.4523	27.91328	0.002825	38		165
13.9585	3.206584	3.726791	5.15E-05	40.5		166
12.6411	7.071866	8.095187	0.00017	40.5		167
4.541706	10.54319	11.04481	0.00027	40.5		168
-0.58452	14.74825	14.66254	0.000412	40.5		169
-0.637	16.6134	16.50824	0.000482	40.5		170
0.35693	21.38114	21.45773	0.000667	40.5		171
-0.48338	28.10906	27.97384	0.00093	40.5		172
-0.92415	29.83729	29.56407	0.001	40.5	Q-425	173
-1.09335	34.53038	34.15693	0.001206	40.5		174
0.24563	37.4645	37.55675	0.00137	40.5		175
2.591007	37.81131	38.81706	0.001394	40.5		176
3.065581	39.23998	40.48096	0.001545	40.5		177
3.40868	39.11948	40.5	0.001671	40.5		178
0.700801	37.47424	37.73872	0.001956	40.5		179
-22.8162	0.6235	0.507669	3.03E-06	41		180
-15.1572	2.309658	2.005656	5.15E-05	41		181
-12.5941	5.798578	5.149986	0.000158	41		182
-5.92282	10.23593	9.663572	0.0003	41		183
-2.39722	12.92523	12.62264	0.0004	41	F-400	184
-4.31488	14.46391	13.86563	0.000461	41		185
0.722315	16.21522	16.3332	0.00053	41		186
1.781548	18.78062	19.12128	0.00063	41		187

1.496818	20.89052	21.20796	0.000709	41		188
0.493369	23.00436	23.11842	0.000785	41		189
-3.84586	29.24208	28.15912	0.001	41		190
-0.40843	35.79961	35.65399	0.0014	41		191
5.661766	36.88162	39.0951	0.001685	41		192
4.272165	39.24841	41	0.002024	41		193
-0.99476	40.72185	40.32076	0.002261	41		194
1.00943	37.86016	38.24623	0.002712	41		195
-0.22807	37.45697	37.37174	0.003	41		196
0.17163	33.73762	33.79562	0.004003	41		197
-1.12371	29.64968	29.32021	0.004915	41		198
1.111883	26.83759	27.13935	0.005867	41		199
-1.89478	4.98566	4.89295	5.45E-05	46.5		200
-2.1509	9.324288	9.127955	0.00017	46.5		201
-2.41831	12.24097	11.95194	0.000252	46.5		202
-2.49477	13.68711	13.35396	0.000294	46.5		203
-0.43663	17.1855	17.11079	0.0004	46.5		204
-0.4894	18.16689	18.07842	0.00043	46.5		205
0.084308	23.94106	23.96126	0.000612	46.5		206
-0.00512	29.03718	29.0357	0.000782	46.5		207
-0.04462	33.57045	33.55547	0.000948	46.5		208
-0.51444	38.4623	38.26545	0.001158	46.5		209
-0.96422	44.16576	43.74397	0.001479	46.5		210
0.121067	46.04419	46.1	0.001727	46.5		211
-0.48594	46.08659	45.86372	0.001773	46.5		212
-5.32792	46.04317	43.71412	0.002064	46.5		213
-0.44469	39.82474	39.64843	0.002448	46.5		214
0.180609	34.88114	34.94425	0.002809	46.5		215
0.943047	31.01782	31.31312	0.0032	46.5		216
0.172911	28.27006	28.31902	0.003688	46.5		217

Prediction of Mechanical Properties of Local Concrete in Compression Using Artificial Neural Networks

Baylasan Mohamad¹, Soleman Alamoudi², and Abd alrahman Issa^{3,*}

¹ Al-Baath University, Homs, Syria, E-mail: Baylasan_m@hotmail.com

² Assistant Professor in structural engineering department, Al-Baath University, Homs, Syria, E-mail: dr.s.amoudi.1@gmail.com

³ Professor in structural engineering department, Al-Baath University, Homs, Syria.

* Baylasan Mohamad, E-mail: Baylasan_m@hotmail.com

Published online: 31 March 2020

Abstract— Mechanical properties of concrete are highly dependent on the local materials used in its preparation. experiments on ready mix concrete in our region illustrate the actual behavior of concrete produced by local materials. Six standard cylinders (D=150mm, H=300mm) were casted of most ready mix concrete in central area in Syria (13 of them) covering a wide range of compressive strength (22 → 46.5)MPa. Tests were carried out using a testing machine which gives the applied force values and the corresponding displacement simultaneously until failure. The mean curves representing the (stress-strain) relationship of concrete in compression are drawn, from which the mechanical properties of each mixture were derived, such modulus of elasticity E_c , compressive strength f'_c , and the corresponding strain ϵ_{co} . Artificial neural networks were trained on experimental test results (using MATLAB). The laws of concrete behaviour were well assimilated by Artificial neural networks, which is possible to be used as an alternative method of available models of stress-strain relationship, by predicting the curve directly for various concrete mixtures prepared using local materials with different mixing ratios, or a complementary method through the adoption of an appropriate mathematical model and then predict its parameters (E_c , f'_c , ϵ_{co}). ANNs proved their ability to predict mechanical properties of concrete better than linear regression equations, which promises a more accurate and comprehensive prediction.

Keywords—: stress- strain, modulus of elasticity, artificial neural networks.